Mirosław Łącki
Akademia Morska w Gdyni

MODEL ŚRODOWISKA WIELOAGENTOWEGO W NEUROEWOLUCYJNYM STEROWANIU STATKIEM

W artykule tym przedstawiono propozycję użycia neuroewolucyjnego systemu wieloagentowego do wspomagania decyzji manewrowych sternika statku płynącego na ograniczonym obszarze wodnym. W środowisku tym sternik jest osobnikiem określonej populacji, która za pomocą algorytmów ewolucyjnych oraz metod uczenia ze wzmocnieniem dostosowuje się do wyznaczonego zadania, jakim jest bezpieczne przepłynięcie danego obszaru przez wyznaczone jednostki pływające.

WSTĘP

Jednym z zadań sztucznej inteligencji jest utworzenie autonomicznych jednostek obliczeniowych, zwanych agentami, zdolnych do szybkiego dostosowania się do zmian zachodzących w złożonych, dynamicznych środowiskach. Dodatkowo agent taki, jeśli znajduje się w środowisku wieloagentowym, musi wykazywać się umiejętnością komunikacji z innymi agentami oraz zdolnością do postrzegania i reagowania na zmiany zachodzące w środowisku.

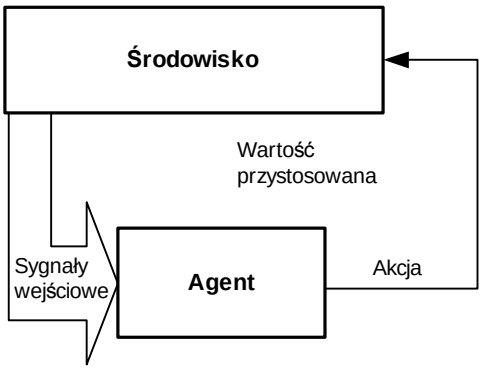

Rys. 1. Interakcja agenta ze środowiskiem

W wyniku interakcji ze środowiskiem (rys. 1) modyfikacji podlega punktowa wartość przystosowania agenta do bieżącej sytuacji. Oddziaływanie agenta na środowisko w przypadku sterowania statkiem polega na wybraniu przez niego jednej

z założonych w projekcie wartości kąta wychylenia steru statku. Statek jest elementem środowiska, na którego parametry (tj. kurs, prędkość kątową itp.) ma wpływ ciąg decyzji podejmowanych przez agenta.

W elemencie ewolucyjnym systemu taki agent jest jednym z osobników populacji rywalizującym z innymi osobnikami o jak najlepszą pozycję w rankingu. Proces uczenia się agenta w środowiskach o niewielkiej dynamice zmian może być realizowany klasycznymi metodami jak uczenie się ze wzmocnieniem (ang. *reinforcement learning*) [12] lub przy użyciu sztucznych sieci neuronowych ze stałą topologią sieci. Uczenie się ze wzmocnieniem było rozpatrywane w poprzednich badaniach autora dotyczących wspomagania podejmowania decyzji podczas manewrowania statkiem [8]. Problem dużej przestrzeni stanów w takim podejściu można częściowo rozwiązać za pomocą kodowania zgrubnego stanów [11, 13]. Taka metoda obniża dokładność symulowanego modelu, ale poprawia zdolność uczenia się agenta w danym środowisku.

W przypadku środowisk dynamicznych z dużą przestrzenią stanów klasyczne podejście nie jest tak wydajne jak metody neuroewolucyjne [5, 7].

1. EWOLUCYJNE SIECI NEURONOWE

W neuroewolucji sztuczna sieć neuronowa jest traktowana jako osobnik w populacji wielu sieci neuronowych. Najlepiej przystosowane osobniki stają się w wyniku selekcji i krzyżowania rodzicami nowego pokolenia, które dziedziczy cechy przodków. Nowe osobniki poddawane są procesowi mutacji, dzięki czemu w populacji mogą się pojawić osobniki o lepszym przystosowaniu. W wyniku mutacji mogą zostać zmienione nie tylko wartości wag, ale także liczba warstw lub liczba neuronów w warstwie.

Podejście neuroewolucyjne nasuwa kilka istotnych pytań dotyczących efektywności rozwoju sztucznych sieci neuronowych poprzez ewolucję: Jak powinien wyglądać genotyp osobnika odwzorowujący strukturę sieci neuronowej? Jak przeprowadzać krzyżowanie osobników, by nie utracić istotnych informacji z poprzednich pokoleń? Jak uchronić nowe rozwiązania przed zbyt wczesną eliminacją z populacji? Na wszystkie te pytania można znaleźć odpowiedź, używając rozwiązań zastosowanych w sieciach NEAT [9].

W sieciach NEAT (ang. *NeuroEvolution of Augmenting Topologies*) za pomocą algorytmów ewolucyjnych poszukiwane są wartości wag połączeń między neuronami oraz rozwijana jest topologia sieci – od najprostszej struktury początkowej do wyspecjalizowanej złożonej struktury przystosowanej do rozwiązywanego problemu [14]. Metoda NEAT zawiera rozwiązania dla trzech głównych wyzwań ewolucyjnego udoskonalania sieci neuronowych:

- Zacznij od prostej struktury neuronowej i rozwijaj ją, dodając nowe połączenia i neurony, tak by wyewoluować najefektywniejsze rozwiązanie zadanego problemu [2].

- Podczas krzyżowania łącz ze sobą tylko geny historycznie zgodne, tak by umożliwić przekazywanie istotnych informacji potomkom danego pokolenia pomimo różnic w strukturze sieci neuronowych rodziców [1, 4].
- Chroń innowacyjne rozwiązania przed zdominowaniem przez doświadczone osobniki poprzez podział gatunkowy populacji [9].

Aby skutecznie realizować operacje genetyczne, potrzebna jest odpowiednia reprezentacja genetyczna struktury sieci neuronowej [6].

2. SYGNAŁY WEJŚCIOWE SZTUCZNEJ SIECI NEURONOWEJ

W symulowanym środowisku sygnały wejściowe o charakterze ciągłym zostały zakodowane do postaci binarnej. System umożliwia też wykorzystanie informacji o charakterze rozmytym lub wielokryterialnym [3]. W wersji podstawowej opracowanego przez autora systemu rozpatrywane były następujące sygnały wejściowe (rys. 2):

- aktualny kurs statku ψ,
- prędkość kątowa r,
- czy kurs jest kolizyjny (wartość binarna),
- odległość do celu d,
- kąt do celu Φ,
- czy niebezpieczeństwo wzrosło (wartość binarna),
- czy niebezpieczeństwo zmalało (wartość binarna),
- statek zbliża się do celu (wartość binarna),
- cel jest widoczny (wartość binarna),
- kąt wychylenia steru δ.

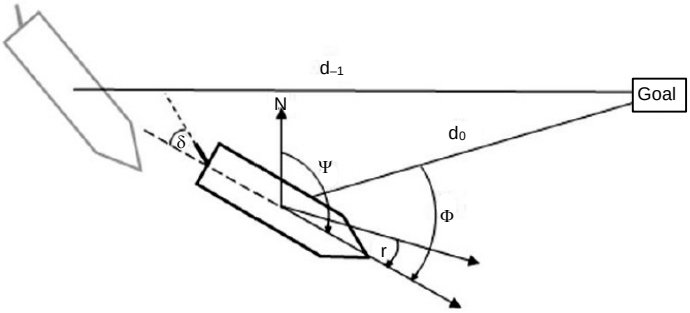

Rys. 2. Podstawowe sygnały wejściowe sieci neuronowej

W udoskonalonym modelu symulacji do podstawowych sygnałów wejściowych dodano także sygnały związane z punktami trasy (rys. 3), tj. odległość i kąt do najbliższego oraz następnego punktu trasy. Dodanie algorytmu wyznaczania pomocniczych punktów trasy do podstawowego systemu było skutkiem obserwacji wyników symulacji złożonych sytuacji manewrowych, tj. tras przejścia o dużej złożoności wymagającej często ostrych zwrotów statku.

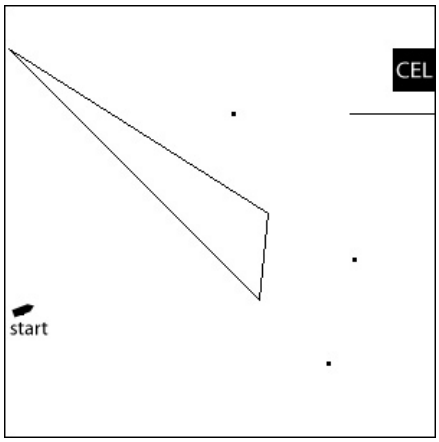

Rys. 3. Środowisko symulacyjne manewrowania statkiem na ograniczonym obszarze z wyznaczonymi trzema punktami trasy

Symulacje bez pomocniczych punktów trasy wykazały duży rozrzut czasowy oczekiwania na uzyskanie efektywnego rozwiązania wynikający z dużej przestrzeni stanów, którą sieć neuronowa eksploruje podczas poszukiwania wartościowych rozwiązań.

3. SYGNAŁY WYJŚCIOWE

W uproszczonym modelowanym systemie wspomagania decyzji opartym na sieci neuronowej ważne jest określenie liczby wyjść sieci, czyli liczby kątów wychylenia steru. Większa liczba wyjść sieci oznacza większą złożoność sieci, ale też lepsze odwzorowanie symulowanego modelu. Zbyt duża liczba wyjść może jednak znacznie zmniejszyć szybkość uczenia się sternika i obniżyć jego zdolność przystosowywania się do nowych sytuacji nawigacyjnych.

Zakładając przedział kąta wychylenia steru od –35° do +35° w symulacji zastosowano 11 sygnałów wyjściowych o skoku wychylenia steru co 7°: –35°, –28°, –21°, –14°, –7°, 0°, 7°, 14°, 21°, 28°, 35°.

4. ŚRODOWISKO WIELOAGENTOWE

Środowiska wieloagentowe służące do wspomagania decyzji manewrowych na ograniczonym obszarze wodnym można podzielić na dwie kategorie:

- system wieloagentowy dla pojedynczego statku,
- system wieloagentowy dla wielu statków.

Model pierwszy dotyczy sytuacji, w której chcemy wytrenować sternika zdolnego bezpiecznie przeprowadzić dany model statku przez ograniczony obszar wodny od pozycji startowej do wyznaczonego celu (rys. 4). Pozostałe jednostki na danym obszarze poruszają się po wstępnie wyznaczonych trasach i jednym z zadań populacji trenowanych agentów sterujących pojedynczym statkiem jest dostosowanie swego zachowania do sytuacji na danym obszarze. W tym modelu trenowanie agentów jest symultaniczne, tzn. agenci nie komunikują się między sobą.

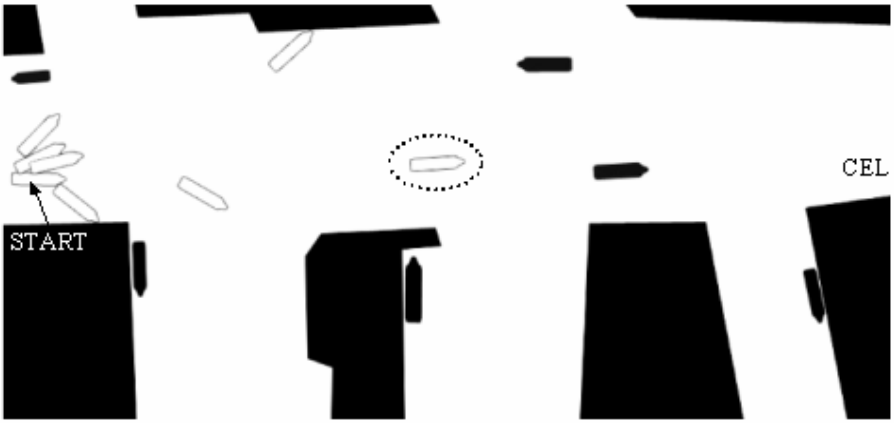

Rys. 4. Przykład środowiska wieloagentowego populacji sterników pojedynczego statku. W danym momencie czasowym z badanej populacji (białe jednostki) można wyodrębnić najlepszego sternika

W drugim przypadku populacje agentów sterują kilkoma różnymi jednostkami pływającymi, z których każda ma inną pozycję startową oraz inny wyznaczony cel (rys. 5). Ten model wymaga komunikacji agentów między sobą w celu uniknięcia kolizji.

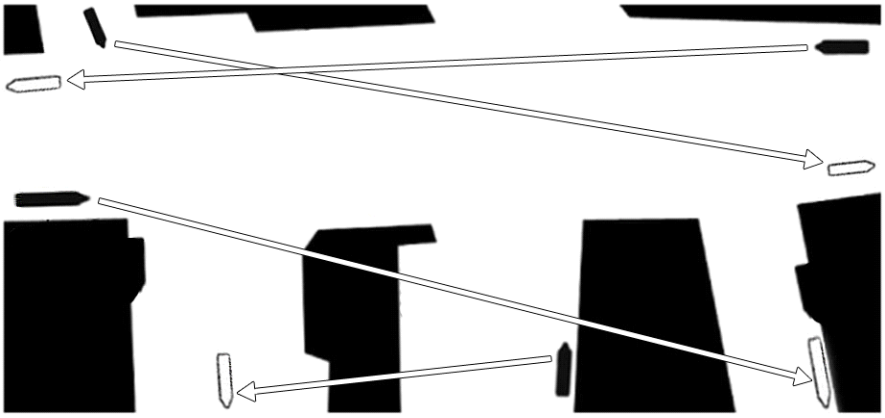

Rys. 5. Przykład środowiska wieloagentowego trenującego sterników kilku statków. W tym przykładzie czterej agenci mają odrębne zadania bezpiecznego przejścia czterech statków na tym samym ograniczonym obszarze

WNIOSKI

Metody neuroewolucyjne zastosowane w rozwiązywaniu zadań w środowiskach wieloagentowych wykazują dużą efektywność nawet w złożonych sytuacjach manewrowych. Dzięki temu model środowiska symulującego bezpieczne przejście pojedynczego statku lub grupy statków przez ograniczony obszar wodny może być bardziej złożony, czyli dokładniej odwzorowywać sytuację rzeczywistą. Dodatkową zaletą neuroewolucyjnego systemu wieloagentowego jest zdolność do uczenia agentów podejmowania decyzji na różnych jednostkach pływających oraz dla różnych sytuacji manewrowych.

LITERATURA

1. Beyer H.G., Schwefel P.H., *Evolution strategies A comprehensive introduction*, Natural Computing, 2002, 1(1).
2. Braun H., Weisbrod J., *Evolving feed-forward neural networks*, Proceedings of ANNGA 93, International Conference on Artiffcial Neural Networks and Genetic Algorithms, Springer, Berlin 1993.
3. Filipowicz W., Łącki M., Szłapczyńska J., *Multicriteria decision support for vessels routing*, Proceedings of ESREL05 Conference, Gdańsk 2005.
4. Kenneth O.S., Miikkulainen R., *Effcient Evolution of Neural Network Topologies*, Proceedings of the 2002 Congress on Evolutionary Computation, Piscataway, 2002.
5. Kenneth O.S., Miikkulainen R., *Effcient reinforcement learning through evolving neural network topologies*, Proceedings of the Genetic and Evolutionary Computation Conference (GECCO-2002), CA, Morgan Kaufmann, San Francisco 2002.
6. Kenneth O.S., Miikkulainen R., *Real-Time Neuroevolution in the NERO Video Game*, Proceedings of the IEEE 2005 Symposium on Computational Intelligence and Games, Piscataway, 2005
7. Łącki M., *Ewolucyjne sieci NEAT w sterowaniu statkiem*, Inżynieria Wiedzy i Systemy Ekspertowe, Akademicka Oficyna Wydawnicza EXIT, Warszawa 2009.
8. Łącki M., *Machine Learning Algorithms in Decision Making Support in Ship Handling*, Proceedings of TST Conference, WKL, Katowice–Ustroń 2007.
9. Łącki M., *Neuroevolutionary approach towards ship handling*, Proceedings of TST Conference, WKL, Katowice–Ustroń 2008.
10. Łącki M., *Speciation of population in neuroevolutionary ship handling*, [w:] *Marine Navigation and Safety of Sea Transportation*, red. A. Weintrit, CRC Press/Balkema, Taylor&Francis Group, Boca Raton–London–New York–Leiden, 2009.
11. Sutton R., *Generalization in Reinforcement Learning: Successful Examples Using Sparse Coarse Coding*, Neural Information Processing Systems, 1996, 8.
12. Sutton R., Barto A., *Reinforcement Learning: An Introduction*, MIT Press, 1998.
13. Tesauro G., *Temporal Difference Learning and TD-Gammon, Communications of the Association for Computing Machinery*, 1995, vol. 38, no. 3.
14. Touretzky D., Mozer M., Hasselmo M., *Neural Information Processing Systems*, MIT Press, 1996.

MULTI-AGENT ENVIRONMENT FOR NEUROEVOLUTIONARY SHIP HANDLING

Summary

This paper presents the proposal of multi-agent environment to simulate and demonstrate learning behavior of helmsmen in ship maneuvering. Simulated helmsmen are treated as individuals in population, which through environmental sensing learn themselves to navigate in restricted waters selecting an optimum trajectory of a vessel. Learning phase of the task is to observe current situation and choose the best action. Neuroevolutionary algorithms are used to solve this task. The best fitted individuals from each population become parents for the next generation of helmsmen in simulated multi-agent navigational situation.